

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Maja Trstenjak

Zagreb, 2016.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentori:

Prof. dr. sc. Predrag Ćosić, dipl. ing.

Student:

Maja Trstenjak

Zagreb, 2016.

Izjavljujem da sam ovaj rad izradila samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem se roditeljima i mentoru prof. dr. sc. Predragu Ćosiću.

Maja Trstenjak



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
materijala i mehatronika i robotika

Sveučilište u Zagrebu	
Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

DIPLOMSKI ZADATAK

Student: Maja Trstenjak

Mat. br.: 35185947

Naslov rada na
hrvatskom jeziku:

Podrška odlučivanju pri definiranju redoslijeda operacija

Naslov rada na
engleskom jeziku:

Decision support in assessment of operations sequencing

Opis zadatka:

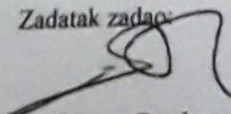
U projektiranju tehnoloških procesa pri određivanju redoslijeda operacija veoma često se koristi intuitivni i heuristički pristup projektanta. Budući da je tu uočljiva subjektivna procjena tehnologa, ograničena njegovim znanjem, iskustvom i moći sinteze, područje određivanja redoslijeda operacija je zahvalno područje za korištenje metoda umjetne inteligencije. U radu će se razviti, primjenom uobičajenih ograničenja, kriterija i podkriterija, mogući scenariji redoslijeda operacija primjenom višekriterijalnog optimiranja i AHP metode. Pri tome će se uočiti prednosti/nedostaci promatrane metode te njezina fleksibilnost na razmatranom problemu.

Zadatak zadan:
5. svibnja 2016.

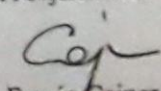
Rok predaje rada:
7. srpnja 2016.

Predviđeni datum obrane:
13., 14. i 15. srpnja 2016.

Zadatak zadao:


Prof. dr. sc. Predrag Čosić

Predsjednik Povjerenstva:


Prof. dr. sc. Franjo Čajner

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	III
POPIS TABLICA.....	IV
POPIS KRATICA	V
SAŽETAK.....	VI
SUMMARY	VII
1. UVOD.....	1
2. CAPP	2
2.1. Funkcija CAPP-a.....	2
2.2. Općeniti CAPP model.....	3
2.3. Arhitektura CAPP-a	4
2.4. Prednosti korištenja CAPP sustava	5
2.5. Varijantni pristup CAPP-a	6
2.5.1. Prednosti varijantnog pristupa	6
2.6. Generativni pristup CAPP.....	6
2.7. Uštede korištenjem CAPP-a.....	7
2.8. Primjena	7
3. PLANIRANJE TEHNOLOŠKIH PROCESA I REDOSLIJEDA OPERACIJA	8
3.1. Određivanje redoslijeda operacija.....	8
3.1.1. Tradicionalan pristup	9
3.1.2. ProPlanner.....	9
3.1.3. ISOS – genetski algoritam	11
3.1.4. Problem putujućeg trgovca – SAT algoritam	11
3.1.5. SA algoritam	12
4. Povezanost određivanja redoslijeda operacija i CAPP-a.....	13
5. Podrška odlučivanju.....	14
5.1. Odlučivanje i određivanje redoslijeda operacija	14
5.2. AHP metoda.....	14
5.2.1. Prednosti i nedostaci AHP metode	16
6. Određivanje redoslijeda operacija korištenjem AHP metode.....	18
6.1. Opis izratka	18
6.2. Kriteriji i opis kriterija	26
6.3. Prijedlozi za minimizaciju utjecaja subjektivnosti u AHP procesu	29
6.3.1. Strukturiranje brainstormingom	30
6.3.2. Struktura i broj kriterija	30
6.3.3. Problem kvalitativnih kriterija	32
6.3.4. Problem broja alternativa	34
7. OBRADA PODATAKA I REZULTATI	35
7.1. Modifikacije procesa – razni scenariji:	35

7.1.1. Fina/gruba obrada	35
7.1.2. Kraće vrijeme izrade – pripremno-završno i pomoćno.....	38
7.1.3. Paletni sustav i napredne vrste stezanja	38
7.1.4. Manja cijena radnog sata.....	39
7.2. Evaluacija rezultata	40
8. ZAKLJUČAK.....	42
LITERATURA.....	43
PRILOZI.....	45
Prilog 1 – odabir primarnog procesa	46
Odabir primarnog procesa prema Haleviju	46
Odabir primarnog procesa po ASM-u	47
Moguće nedoumice	48
Konačni odabir	48
Odabir osnovnih operacija	49
Površina 1.....	51

POPIS SLIKA

Slika 1.	CAPP model [6]	3
Slika 2.	Arhitektura CAPP sustava [6]	4
Slika 3.	Shema ProPlanner sustava [17]	10
Slika 4.	Struktura problema u AHP metodi [21]	15
Slika 5.	Saatyjeva skala (brojčana) [22]	15
Slika 6.	CAD crtež osovine [26].....	19
Slika 7.	Izrada površine 1 [26].....	20
Slika 8.	Izrada površine 2 [26].....	20
Slika 9.	Izrada površine 3 [26].....	21
Slika 10.	Izrada površine 4 [26].....	21
Slika 11.	Izrada površine 5 [26]	22
Slika 12.	Plan stezanja 1 [26]	23
Slika 13.	Plan stezanja 2 [26]	23
Slika 14.	Plan stezanja 3 [26]	24
Slika 15.	Struktura AHP modela [21].....	30
Slika 16.	Loše strukturirani kriteriji	31
Slika 17.	Primjer dobro strukturiranih kriterija	32
Slika 18.	Ilustracija postupka određivanja međusobne važnosti alternativa	33
Slika 19.	Rezultati AHP metode.....	35
Slika 20.	Rezultati s novim kriterijem „Fina/gruba obrada“	36
Slika 21.	Rezultati i utjecaj kriterija s novim kriterijem „Fina/gruba obrada“	36
Slika 22.	Rezultati – smanjeno tehnološko vrijeme	38
Slika 23.	Rezultati – povećan utjecaj tehnoloških kriterija	39
Slika 24.	Rezultati – manja cijena radnog sata	40
Slika 25.	Klasifikacija složenosti oblika po Haleviju [14]	46
Slika 26.	Odabir vrste oblikovanja prema Haleviju [14].....	46
Slika 27.	Klasifikacija oblika po ASM-u [13]	47
Slika 28.	ASM – kompatibilnost materijala i postupaka [13]	47
Slika 29.	Hrapavost površine kod određenih obrada [8]	49
Slika 30.	Hrapavost površine kod tolerancija [8]	50
Slika 31.	Obrade i geometrijske tolerancije [8]	50
Slika 32.	Površina 1	51

POPIS TABLICA

Tablica 1. Vremena obrade [26].....	25
Tablica 2. Kvalitativni/kvantitativni kriteriji.....	29

POPIS KRATICA

AHP – analitički hijerarhijski proces

CAD – *Computer Aided Design*

CAM – *Computer Aided Manufacturing*

CAPP - *Computer Aided Process Planning*

ISOS - *Integrated setup planning and operation sequencing*

SAT - *Simulated annealing technique*

SA - *Simulated annealing*

SAŽETAK

Određivanje redoslijeda operacija jedna je faza životnog vijeka proizvoda. Obično je naglasak stavljen na odabir primarnog procesa, odabir strojeva i alata te parametara obrade, no na redoslijed operacija kao takav rijetko se stavlja poseban naglasak i obično ovisi jedino o iskustvu i znanju planera procesa. Redoslijed operacija ograničen je tehničkim kriterijima, no na njega utječu i drugi kriteriji iz područja tehnologije, ekonomije, ekologije i ergonomije. Budući da je odabir redoslijeda operacija proces određivanja odluke, na njega će se primijeniti AHP metoda (analitički hijerarhijski proces), implementiran u program *Expert Choice* i pokušat će se analizirati mogućnost realne primjene na izradi jednog strojnog dijela.

Ključne riječi: redoslijed operacija, CAPP, analitički hijerarhijski proces, planiranje tehnoloških procesa, Expert Choice

SUMMARY

Operation sequencing is one phase in product lifecycle. Project is usually based on decisions about primary process, machine tools and tools and process parameters. Operation sequencing is based only on knowledge and experience of process planner. It is mostly limited by technical features, but criteria in field of technology, economy, ergonomics and ecology influence the optimal final order of operations. Since this is basic decision making process it will be analysed with AHP method (analytic hierarchy process), implemented in Expert Choice software to get the information could it be used in production? It will be valuated in case study of production of one part.

Key words: operation sequencing, analytic hierarchy process, CAPP, process planning, Expert Choice

1. UVOD

Trendovi u dinamičnom svijetu poslovanja, kao i u svijetu proizvodnje uvijek teže usklađivanju odnosa između troškova, vremena i kvalitete. Cilj je u što kraćem vremenu proizvesti što kvalitetniji proizvod uz što manje troškove i poštujući zahtjeve održive proizvodnje čime se dolazi do konkurentnosti na tržištu. Budući da biti dobar nije dovoljno dobro, važno je biti najbolji. Stoga je potrebno unaprijediti i optimizirati svaki segment u životnom vijeku proizvoda. Jedan od takvih je i planiranje redoslijeda operacija kojima će se proizvod izraditi. Redoslijed operacija određuje se u dijelu životnog vijeka proizvoda koji se nalazi između faze razvoja i dizajna te fizičke proizvodnje. Započinje se odabirom primarnog procesa, zatim strojeva i alata, parametara obrade te finalno redoslijeda operacija. Teži se k optimizaciji svakog segmenta, pa tako i odabira redoslijeda operacija.

Može li se ta „faza“ unaprijediti, shvaćanjem procesa kao običnog procesa donošenja odluka? Koje su posljedice interdisciplinarnog pristupa određivanju redoslijeda operacija i koja je primjenjivost korištenja analitičkog hijerarhijskog procesa kao potpore pri donošenju odluke prikazat će se na primjeru izrade rotacijski simetričnog strojnog dijela – osovine. Utjecaj čovjeka, odnosno njegove subjektivnosti u cjelokupnom procesu također će biti uzet u obzir.

2. CAPP

CAPP (eng. *Computer Aided Process Planning*) je korištenje računalne tehnologije u cilju planiranja procesa izrade dijela ili sklopa. CAPP je poveznica između CAD-a (računalom potpomognutog dizajna) [1] i CAM-a [2] jer omogućuje planiranje proizvodnje modeliranog dijela s odgovarajućim alatima i strojevima [3]. Planiranje procesa prevodi informacije koje je dizajner dao u obliku 3D modela primjenom CAD softvera te ih povezuje s informacijama danim u CAM sustavima koji sadrže informacije o alatima, strojevima i parametrima obrade [4].

2.1. Funkcija CAPP-a

Proces nastajanja proizvoda započinje dizajnom samog dijela za koji su zaduženi dizajneri koji rade po određenim naputcima. Nakon faze dizajna, na temelju izrađenog modela/crteža, projektanti planiraju tehnološke procese pomoću kojeg će se određeni dio izraditi, određuju alate, strojeve i parametre obrade te finalno redoslijed operacija.

Budući da su ovo dva različita područja često dolazi do nesporazuma između dizajnera/konstruktora i projektanta procesa. Dijelovi i proizvodi obično nisu prilagođeni mogućnostima tehnologije koja je u kompaniji na raspolaganju pa dolazi do vremenskih i novčanih gubitaka. Do nesporazuma dolazi zbog nekomunikacije između dva vrlo važna sektora poduzeća – sektora konstrukcija i proizvodnje. Komunikacijski kanal je ili u potpunosti onemogućen ili na njemu postoje određene barijere. Modernizacijom čitavog sustava i primjenom suvremenih računalnih tehnologija ove prepreke počinju predstavljati sve manji problem.

Najprije je došlo do modernizacije konstrukcije proizvoda primjenom CAD programa koji je omogućio brzu i laku manipulaciju dijelom. Moguća je izrada detaljnijeg dizajna proizvoda te su modifikacije lakše – moguća je lakša izrada varijanta proizvoda ili uklanjanje nastalih grešaka. Također, korištenjem baza podataka omogućen je pristup raznim proizvodima iz arhive ili trenutnog kataloga poduzeća.

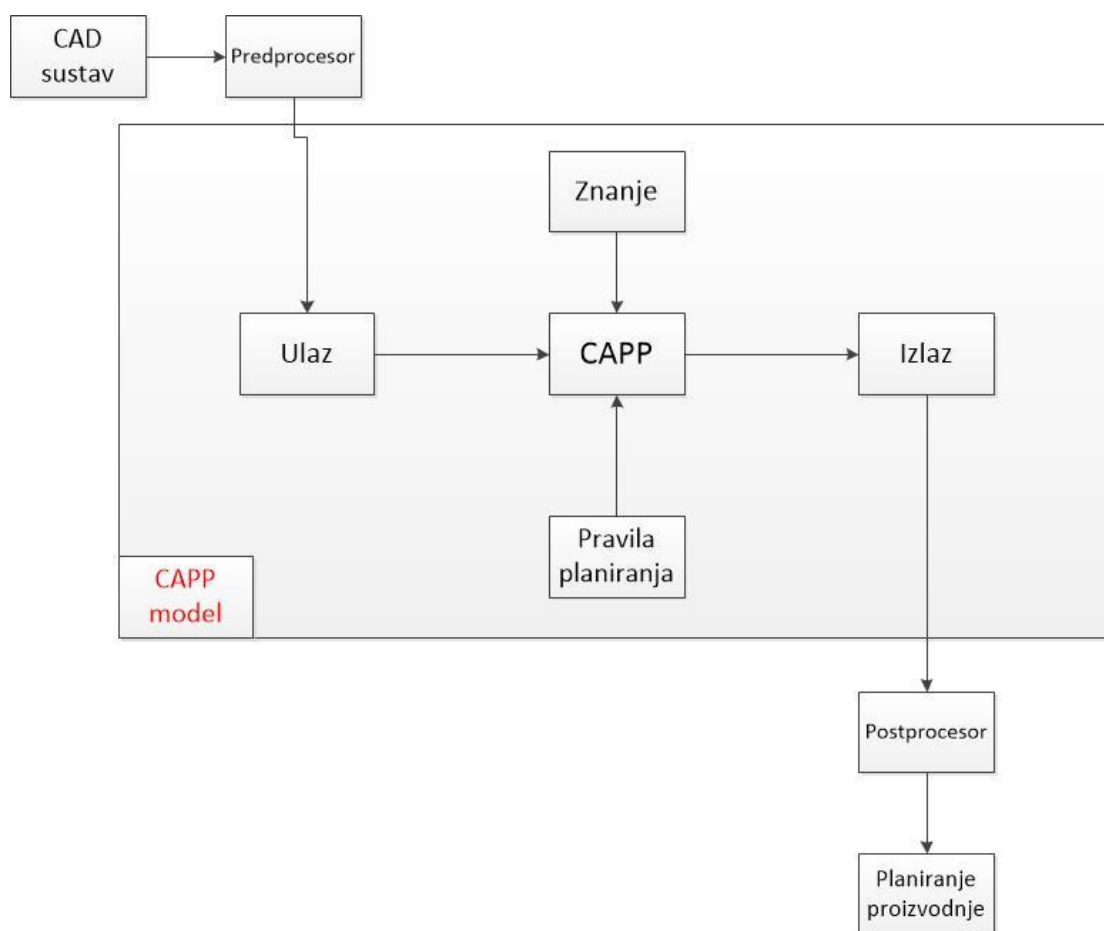
Sljedeći je korak bila implementacija CAM sustava koji omogućavaju manipulaciju alatima, strojevima, parametrima obrade te simulaciju proizvodnog procesa sa svim svojim segmentima. CAM sustavi posjeduju baze podataka dostupnih alata, strojeva i mogućnost određivanja raznih parametara obrade. Simulacija je eliminirala greške nastale zbog krivog procesa obrade koje su često rezultirale oštećenjem alata ili samih strojeva.

Planiranje tehnološkog procesa i redoslijeda operacija je poveznica između procesa konstruiranja i proizvodnje te je kao takva vrlo važan segment u životnom vijeku proizvoda [5].

Automatizacijom čitavog procesa, stvara se čvrsta poveznica između dva važna segmenta koji smanjuje mogućnost pogreške u planiranju i mogućnosti prilagodbe 3D modela dostupnim tehnološkim postupcima, alatima i strojevima. CAPP stoga omogućuje planiranje tehnološkog procesa i redoslijeda operacija pomoću raznih vrsta više ili manje naprednih algoritama implementiranih u računalni softver. Jednostavni su za korištenje te omogućuju uštede vremena i novca te prevenciju nastanka pogrešaka u daljnjem procesu proizvodnje. Dugoročno utječe na kvalitetu samog proizvoda, ali i na njegovu cijenu koja je prihvatljivija za kupca, a zbog manjih troškova povećava se profit proizvođača [4].

2.2. Općeniti CAPP model

Općeniti CAPP model prikazan je na slici 1.




Slika 1. CAPP model [6]

Iz slike 1. vidljiv je položaj CAPP-a u planiranju proizvodnje te njegova struktura. Proizvod se najprije modelira u odgovarajućem CAD sustavu te se dobivene informacije iz modela obrađuju u predprocesoru. Te informacije služe kao ulazni podaci za CAPP sustav koji već sadrži određeno znanje i pravila po kojim se informacije dalje obrađuju i znanje primjenjuje. Izlazne informacije naknadno se obrađuju u postprocesoru, a rezultat je plan proizvodnje koji sadrži informacije o tehnološkim procesima, korištenim alatima, strojevima, parametrima obrade i redoslijedu operacija [6].

2.3. Arhitektura CAPP-a

Arhitektura CAPP sustava prikazana je na Sliku 2.



Slika 2. Arhitektura CAPP sustava [6]

Iz slike 2. vidljivi su segmenti koji čine CAPP i kao takvi utječu na njegovu funkcionalnost i važnost. Informacije iz CAD sustava i predprocesora koriste se za odabir primarnog procesa i ostalih tehnoloških procesa koji se odabiru na temelju podataka iz baze sustava. Na odabir se primjenjuju zadana ograničenja iz druge baze podataka koju sadrži sustav. Pomoću tako obrađenih podataka sustav kreira plan izrade pomoću posebnog modela koji je implementiran unutar njega [6].

2.4. Prednosti korištenja CAPP sustava

Neke od prednosti korištenja CAPP sustava su sljedeće:

- Smanjenje vremena i troškova projektiranja kvalitetnih tehnoloških procesa. Klasični pristup projektiranju tehnoloških procesa obuhvaćao je dulji period u kojem bi se zahtijevalo znanje nekoliko eksperata. Pri tome je njihovo znanje bilo izuzetno važno uz komponentu iskustva koja je povećavala kvalitetu odabranog tehnološkog procesa. Budući da je mogućnosti mnogo, na kraju se često sve svede na metodu pokušaja i pogrešaka što izaziva dodatne troškove zbog pogrešaka koje se mogu desiti pa čak i u nekom drugom trenutku životnog vijeka proizvoda koje snosi tvrtka koja je proizvela proizvod.
- Sistematizacija, kategorizacija i memoriranje znanja za projektiranje. Nepostojanje arhive vrlo je čest problem u proizvodnim tvrtkama. Neke tvrtke čak ne posjeduju niti nacрте za određene proizvode. Stoga je uvođenjem računalnog sustava s velikim bazama podataka sve stavljeno na jedno mjesto, lako je dostupno i pregledno je.
- Optimizacija tehnoloških procesa. Sustav sadrži sva znanja i iskustva dosadašnjih eksperata uz mogućnost spajanja na internet gdje je znanje univerzalno i sveobuhvatno. Sadrži i podatke o dosadašnjim procesima zbog čega je moguće optimizirati tehnološki proces.
- Veća produktivnost projektanata tehnoloških procesa. Projektanti sada troše manje vremena, a i ostaje im vremena za razmišljanje i implementaciju određenih poboljšanja u procesu. Stoga je njihove produktivnost veća. Za kraće vrijeme u mogućnosti su napraviti isti posao.
- Mogućnost povezivanja s ostalim Cax aktivnostima. Osim znanja o projektiranju tehnoloških procesa i redoslijedu proizvodnje, CAPP sustav se povezuje s bazom podataka CAD ili CAM sustava koji sadrže temeljne komponente proizvodnog procesa – podatke o proizvodu, strojevima, alatima i parametrima obrade. Sustav sistematizira ta znanja i optimizira dobivene podatke.
- Smanjene potrebe za visokokvalitetnim tehnolozima, kao i lakše obrazovanje novih projektanata tehnoloških procesa. Znanje eksperata je prilično skupo, a uvođenjem CAPP sustava nije potrebno da svaki projektant bude visokokvalitetan, sustav mu pomaže u radu. Čest je slučaj da u tvrtkama, odlaskom važnog projektanta u mirovinu, novi projektanti kreću od početka zbog nedostatka iskustva što rezultira određenim

gubicima. Sustav pohranjuje podatke o prethodnim radnjama i tako olakšava obrazovanje novih projekatata koji se brzo i lako upoznaju s čitavim proizvodnim procesom [7].

2.5. Varijantni pristup CAPP-a

Tradicionalan pristup varijantnog planiranja tehnoloških procesa i određivanja redoslijeda operacija obuhvaća proučavanje crteža na temelju kojeg se identificiraju slične pozicije u prošlosti. Podaci o njima pronalaze se obično u arhivi gdje su zapisani podaci i o planovima procesa. Ti se planovi adaptiraju ili modificiraju shodno novom zahtjevu.

CAPP sustav omogućuje brz i jednostavan pristup podacima koji se nalaze u računalnoj bazi podataka procesa. Derivirano iz skupnih tehnologija, pozicije su klasificirane i kodirane u familije pozicija – pozicije s atributima dovoljno sličnim zajedničkoj proizvodnoj metodi za sve njih. Svaka familija ima standardni procesni plan koji uključuje sve moguće operacije za familiju i kao takav je pohranjen u sustavu. Standardni plan prilagođuje se novoj poziciji. Kvaliteta samog procesa dodatno u ovom slučaju zavisi i o pozadinskom znanju projektanta.

2.5.1. Prednosti varijantnog pristupa

Prednosti varijantnog pristupa su sljedeće:

- Upotreba postojećih proizvodnih podataka i ekspertize
- Oslobađanje projektanta rutinskih aktivnosti
- Primjena na sve tipove proizvodnje
- Mogućnost nadogradnje promijenjenih proizvodnih tehnologija za nove i stare pozicije
- Uključenje standarda tvrtki
- Procesni plan kompletira poziciju (sve tipove procesa kao montažu, bojanje, skladištenje, marketing itd.)
- Najveća ušteda u pripremnoj fazi projektiranja

2.6. Generativni pristup CAPP

Generativni se pristup bazira na tehnološkim algoritmima koji u sebi sadrže određenu logiku odlučivanja. Koriste se formule i bazni geometrijski podaci na temelju kojih se potpuno

automatski generiraju planovi procesa. Upravo je zbog toga generativni pristup izrazito kompleksan i težak za razvoj, zahtjeva specifična znanja i vještine iz raznih područja. IT stručnjaci trebaju razviti okvir sustava, odnosno algoritma, dok su za sve ostalo, sam sadržaj, zaduženi stručnjaci iz područja projektiranja procesa.

Postoji i semi-generativni pristup koji je kombinacija varijantnog i generativnog pristupa. Isprva radi na principu varijantnog pristupa, no u završnici razrade procesa koristi korake generativnog sustava u nešto modificiranom obliku uz svu logiku odlučivanja, formule, tehnološke algoritme i podatke o geometriji ugrađene u sustav.

2.7. Uštede korištenjem CAPP-a

Iz prednosti koje korištenje CAPP sustava donosi, prikazanih u poglavlju 2.4., proizašle su i konkretne uštede koje se mogu kvalitativno mjeriti. Tako prema nekim izvorima [9] korištenjem CAPP sustava samo planiranje procesa vremenski je smanjeno za 58%, 10% manje je potrebno uložiti direktnog ljudskog rada, 4% je manje materijala potrebno, 12% je manje otpada u čitavom procesu i 12% ušteda u samom proizvodnom procesu.

2.8. Primjena

CAPP je primjenjiv u mnogim granama industrije, a posebna se pažnja pridaje strojnoj obradi u kojoj je ovaj sustav najrazvijeniji. Svaki funkcionira na istom baznom principu, arhitektura je slična, no algoritmi za svaki korak su različiti, ovisno o projektantu. Najprije je razvijen CAPP sustav za rotacijski simetrične dijelove, a nakon je razvijen sustav za nesimetrične i kompleksnije dijelove koji se također može koristiti u planiranju procesa [10], [11], [12], [13].

3. PLANIRANJE TEHNOLOŠKIH PROCESA I REDOSLIJEDA OPERACIJA

Nakon što je dizajn proizvoda razvijen i 3D model je definiran, slijedi planiranje tehnološkog procesa, odnosno operacija kojima će proizvod biti izrađen. Postoji mnogo načina za određivanje primarnog procesa (prilog 1.), sve ovisi o projektantu koji je zadužen za planiranje. Ovisno o njegovom znanju i iskustvu, on odabire metodu za koju smatra da je najpovoljnija i primjenjuje ju na novi proizvod.

Ukoliko već u arhivi postoji sličan proizvod, moguće je da će projektant se odlučiti na iste operacije koje su prethodno korištene, pogotovo ako se radi o varijanti proizvoda koji je vrlo sličan nečemu što je tvrtka već proizvela. No, ukoliko se radi o novom proizvodu, potrebno je odrediti tehnološke procese proizvodnje sukladno obliku, materijalu, dostupnim sirovcima, tolerancijama, zahtjevima kvalitete površine, naknadne toplinske ili površinske obrade. Postoje razvijeni prijedlozi, postupci koje predlaže Halevi [14], ASM [15] ili drugi kojima se određuju točne operacije nakon kojih je potrebno odabrati strojeve, alate i parametre strojne obrade.

Nakon odabranih tehnoloških procesa (prilog 1.), strojeva, alata i parametra strojne obrade potrebno je odrediti redoslijed operacija. Redoslijed operacija često se odabire prema iskustvu projektanta, što je tradicionalan i ustaljen pristup. Operacije se dijele na operacije grube i fine obrade. Gruba obrada obavlja se prva, nakon čega slijedi fina obrada. No, sada se javlja mogućnost više varijanti, odnosno načina strojne obrade. Moguće je za jedan segment, npr. rupu s navojem, najprije obraditi grubo (bušenje), zatim fino (razvrtanje i upuštanje) te na kraju narezati navoj. No moguće je i prvo napraviti grubu obradu (bušenje) te tada krenuti na ostale grube obrade koje su potrebne na komadu ili možda na neke koje zahtijevaju isti alat, pa se uštedi vrijeme na izmjeni alata.

Već na samom je početku vidljiv prostor za automatizaciju cijelog procesa, a to je odrađeno primjenom CAPP sustava i raznih algoritama i metoda koje su razvijene.

3.1. Određivanje redoslijeda operacija

Kroz godine korištenja razvijeno je mnoštvo načina za određivanja redoslijeda operacija. Osim tradicionalnog pristupa, razvijeni su određeni algoritmi koji su implementirani u računalne sustave te su primijenjene metode metaheuristike.

3.1.1. Tradicionalan pristup

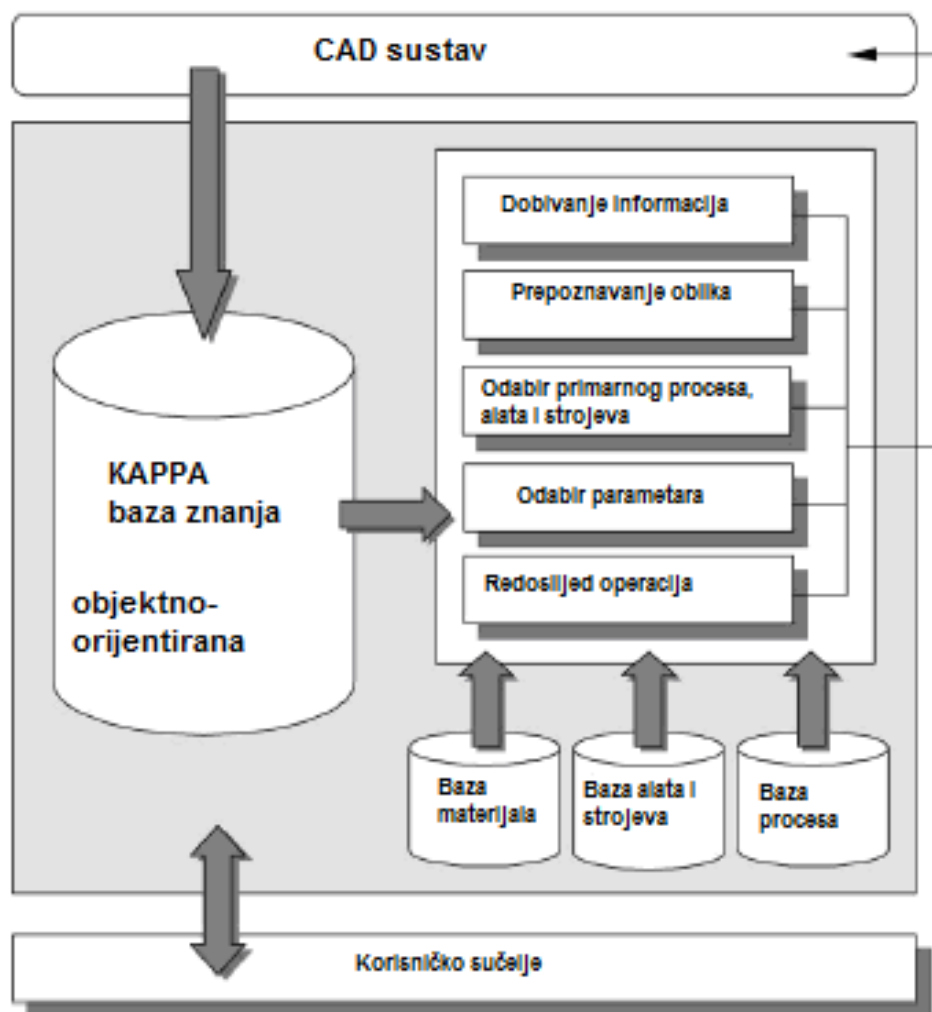
Tradicionalni se pristup oslanja isključivo na znanje i iskustvo projektanta koji sam donosi odluke o redoslijedu operacija na temelju informacija s kojima raspolaže. Često je praksa da se operacije koje najdulje traju obavljaju prve, ukoliko je to moguće. Razmatra se što je financijski najisplativije, no, od samih se gubitaka u procesu eliminiraju najveći i najuočljiviji, kao što je npr. broj stezanja. Projektanti određuju redoslijed operacija da se obrada može obaviti sa što manjim brojem stezanja jer se tako smanjuje pomoćno vrijeme, smanjuje se potreban fizički rad i povećava se efikasnost stroja. Efikasnost stroja u ovom bi se slučaju mogla mjeriti kao omjer tehnološkog vremena i ukupnog vremena koje je zbroj tehnološkog, pomoćnog i pripremno-završnog vremena [16]. Budući da je pomoćno vrijeme manje, a tehnološko i pripremno-završno vrijeme je ostalo isto, efikasnost je veća.

Dodatna činjenica koju projektanti uzimaju u obzir je i amortizacija strojeva, odnosno cijena radnog sata stroja. Ukoliko je na raspolaganju nekoliko posebno specijaliziranih obradnih strojeva, koji nisu CNC obradni centri, tada će operacije biti raspoređene sukladno cijeni radnog sata stroja u ovisnosti o njihovoj raspoloživosti. Moguće je da će se određene operacije dobiti redoslijed isključivo po raspoloživosti strojeva zbog cijene, ili čak raspoloživosti strojeva općenito. Također, obradni centri s višom cijenom radnog sata imaju veću produktivnost, dakle utječu na rok isporuke ako se radi o velikoj količini izradaka. I sama razina automatiziranosti stroja, primjerice automatska dobava šipkastog materijala, korištenje paletnog sustava radi "prekrivanja" tehnoloških vremena pomoćnim vremenima, uređajima za fiksiranje po visini i slično, utječe na finalnu odluku. Fine obrade se obično ostavljaju za sam kraj i njima se pridaje posebna pažnja kako bi finalni proizvod bio što kvalitetniji.

3.1.2. ProPlanner

ProPlanner je računalni sustav koji je stvoren u svrhu određivanja redoslijeda operacija 2001. godine. Integrira nekoliko kompjuterskih alata koristeći bazu znanja i rasuđivanje paradigme s obzirom na ograničenja obradnih procesa i mogućnosti postojećeg strojnog parka. Sustav sadrži pet ključnih modula za prikupljanje informacija, prepoznavanje oblika, planiranje operacija obrade, izbor alata, izbor parametara obrade i redoslijeda operacija. Kombinira informacije iz faze dizajna i prilagođuje ih planiranju procesa. Povezuju se i s bazama podataka (slika 3.) koje se sastoje od podataka o proizvodima i dodatnim bazama koje sadrže

općenite informacije o procesima, alatima i materijalima te sadrže korisničko sučelje za komunikaciju i upravljanje.



Slika 3. Shema ProPlanner sustava [17]

Iz slike 3. vidljiva je shema *ProPlanner* sustava. Povezuje dva velika područja – CAD sustav i KAPPA-PC sustav za razvoj ekspertnih sustava koji upravlja s glavnim modulima koji se generiraju s obzirom na podatke dobivene iz tri glavnih baza podataka – bazi materijala, alata i procesa obrade.

Program pretpostavlja da postoji nekoliko mogućih shema svakog zadanog oblika te on s obzirom na to generira sve moguće kombinacije redoslijeda operacija. Glavno ograničenje (kriterij) pomoću kojeg sustav dolazi do optimalnog rješenja je najmanji broj izmjene alata. Osim toga, uzima u obzir i dimenzijske tolerancije i zahtjeve na površinsku hrapavost [17].

3.1.3. ISOS – genetski algoritam

ISOS (eng. *Integrated setup planning and operation sequencing*) je sustav koji koristi genetski algoritam i glavna mu je zadaća popuniti funkcionalnu rupu između CAD-a i CAM-a. Dan je kao prijedlog, odnosno nadogradnja postojećih CAPP sustava jer rezultati njihova rada nisu bili optimalni. Osim određivanja redoslijeda operacija, ISOS se bavi i planiranjem postavka strojeva i samih operacija te daje rezultate bliže optimalnom rješenju. Glavni je cilj uskladiti dva velika kriterija koja utječu na proizvodnost – ukupno vrijeme izrade i cijena proizvodnje. Do rješenja se dolazi analizom i obradom podataka dobivenih iz geometrijskih značajki izratka koji su glavni ulazni podaci. ISOS se bazira tako na tri elementa – optimizirani plan postavki operacija, optimizirani plan redoslijeda operacija i optimiziran odabir stroja, alata i parametara obrade. Ograničenja pristupa leže u broju osi stroja, odnosno načinu gibanja po osima, prednosti vezanih obrada (obrada koje nužno trebaju slijediti jedna nakon druge, kao npr. obrade u nekom provrtu), dostupnim steznim napravama (prednost imaju stezne naprave koje se najčešće koriste), povezanosti određenih značajki geometrijskim tolerancijama (parametri obrade određuju se jedna u odnosu na drugu značajku) te ustaljenim preporukama za kvalitetnu obradu.

Genetski algoritam oponaša proces prirodne evolucije u kojoj preživljavaju najbolja rješenja uz strukturirane i slučajne izmjene informacija. Prva faza je inicijalna populacija koja opisuje predstavnike mogućih rješenja. Svaki element (gen) predstavlja operaciju, a poredak elemenata u mreži (kromosomu) je redoslijed operacija. Finalni rezultat je plan procesa predstavljen slučajnom kombinacijom gena. Operator mutacije je slučajan odabir određenih rješenja. Funkcija troškova procesa u ovom slučaju je pokazatelj kvalitete odabranog procesa i redoslijeda. Sastoji se od kriterija amortizacije strojeva i alata, troškovima promjene alata i parametara te dodatnih troškova zbog određenih gubitaka. To je optimizacijska funkcija algoritma čiji je minimum optimalno rješenje. Ovim se genskim algoritmom uspjelo približiti optimalnom rješenju jer su osim tehnoloških uvedeni i ekonomski kriteriji koji su postavljeni kao glavna funkcija cilja [18].

3.1.4. Problem putujućeg trgovca – SAT algoritam

Problem putujućeg trgovca rješava određivanje redoslijeda operacija implementacijom u tzv. SAT tehniku (eng. *Simulated annealing technique*). SAT je metaheuristički algoritam kojem je cilj minimizirati matricu troškova, što daje optimalno rješenje s najnižom cijenom, ali također i nastoji smanjiti vrijeme obrade podataka. Matrica se troškova kreira s obzirom na

dizajn proizvoda i attribute njegove proizvodnje (broj strojeva, izmjena alata, tehnološka vremena). Rezultat, redoslijed operacija je hamiltonska ruta minimalnog troška koja prolazi kroz vrhove (attribute) samo jednom. To je struktura u literaturi poznata kao problem putujućeg trgovca. Svaki kriterij obrade prolazi kroz SAT algoritam koji evaluira troškove i na temelju njega se kreira matrica troškova. Optimizacija matrice je np-težak kombinatorni problem, stoga se rješava heurističkim metodama. Dobivene je rezultate moguće primijeniti u praksi, a prvotna namjera minimizacije troškova i smanjenja vremena proračuna je uspješno postignuta [19].

3.1.5. SA algoritam

SA (eng. *Simulated annealing*) algoritam temelji se na geometrijskim osobinama izratka. Geometrijske i negeometrijske kompleksnosti koje se javljaju u čitavom sustavu stavljene su na centralno mjesto razmatranja te se na temelju njih stvara algoritam optimizacije određivanja redoslijeda operacija. Također, uzet je u obzir i orijentacija dijela pri stezanju, kompatibilnost alata, dostupnost obratka, dimenzijske tolerancije, geometrijske tolerancije i zahtijevana kvaliteta površine. Pritom se generira indeks promjene položaja, promjene alata i indeks kontinuiranosti obrade. Indeksima su dodijeljene funkcije važnosti i zajednička funkcija cilja čiji optimum predstavlja redoslijed operacija. Algoritam traži globalni optimum uz pretpostavku minimizacije broja stezanja i izmjene alata te maksimizaciju kontinuiranosti obrade .

4. Povezanost određivanja redoslijeda operacija i CAPP-a

Funkcijsku prazninu između CAD-a i CAM-a potrebno je povezati i ispuniti, što treba biti uloga CAPP sustava. Stoga bi on kao takav trebao omogućiti automatizirani proces određivanja primarnog procesa, odabira strojeva, alata i parametara te određivanja redoslijeda operacija. U teoriji je prilično dobro zamišljen, no određeni su segmenti ostali još uvijek nedefinirani i isključivo individualizirani kod uporabe CAPP-a, koja ovisi o korisniku. Kako bi se proces proizvodnje odvijao ekonomično, potrebno je odrediti optimalan redoslijed operacija. Funkcija CAPP-a kao takvog bi trebala ponuditi automatizirano određivanje redoslijeda operacija, no generalno, optimalno, općeprihvaćeno i široko rasprostranjeno rješenje još uvijek nije poznato. Budući da se određivanje redoslijeda operacija dosad prihvaćalo kao radnja koju određuje ekspert u tom području, on se pritom oslanja isključivo na vlastito iskustvo, intuiciju i znanje, što često dovodi do problema. Automatizacijom određivanja redoslijeda operacija i implementacijom rješenja u CAPP sustav poboljšao bi se jedan dio u životnom vijeku proizvoda.

Budući da se ovdje radi o tipičnom procesu donošenja odluka, prijedlog automatizacije jest korištenje sustava za potporu odlučivanju. Metoda koja je jednostavna za korištenje i čija je logika lako shvatljiva je analitički hijerarhijski proces (AHP metoda) integrirana u *Expert Choice* program. Ukoliko se metoda pokaže korisnom, njena integracija u CAPP sustav riješila bi problem automatizacije jednog koraka, odnosno popunjavanja dijela praznine između CAD-a i CAM-a koja trenutno stvara određene probleme.

5. Podrška odlučivanju

U svakodnevnom se životu susrećemo sa situacijama u kojima je vrlo važno donijeti ispravnu odluku između mnogobrojnih mogućnosti premda i ponekad nismo sigurni koja bi mogućnost od tih bila najbolja. Isti se problem javlja i u poslovnom svijetu u kojoj su situacije prilično složene, opisane s mnogo podataka, a posljednice odluke su vrlo značajne. Ukoliko odluka nije ispravna, ona bi se mogla negativno odraziti na buduće rezultate i donijeti gubitke u raznim oblicima i količinama.

5.1. Odlučivanje i određivanje redoslijeda operacija

Određivanje redoslijeda operacija može se poistovjetiti s radnjom odlučivanja. Svaki proizvod se treba izraditi s određenim brojem odabranih operacija (procesa), na odabranim alatima, strojevima i parametrima obrade. Svaka operacija, svaki korak u procesu proizvodnje ima određene karakteristike koje se finalno odražavaju na gotov proizvod i njegovu primjenu. Karakteristike procesa koji su na raspolaganju mogu se poistovjetiti s kriterijima odlučivanja, a sami procesi su alternative. Konačna odluka, odnosno redoslijed operacija mogao bi se usvojiti kao redoslijed povoljnih rješenja – od najpovoljnijeg do najmanje povoljnog. Ovisno o situaciji i utjecaju pojedinih kriterija na rezultat potrebno je odabrati hoće li se najmanje povoljne operacije najprije izvoditi ili će se prvo izvesti najviše povoljne operacije.

U mnoštvu dostupnih alata za podršku odlučivanju, daljnjem će slučaju biti korištena AHP metoda koja je implementirana u softver *Expert Choice* pomoću kojeg će se generirati finalni rezultat.


5.2. AHP metoda

Jedna od najkorištenijih i najpopularnijih metoda za donošenja odluka u poslovnim okruženjima je AHP metoda (*analitički hijerarhijski proces*) koja omogućuje odabir najznačajnijeg kriterija i alternative.

AHP metoda sastoji se od sljedećih faza:

- Strukturiranje problema
- Određivanje najznačajnijeg kriterija
- Određivanje najznačajnije alternative
- Određivanje konačnog rješenja (cilja)


Struktura problema u AHP metodi sastoji se od razine cilja, razine kriterija, razine potkriterija i razine alternativa (slika 4.)



Slika 4. Struktura problema u AHP metodi [21]

Iz slike 4. je vidljivo kako je cilj hijerarhijski na samom vrhu problema te je on optimalno rješenje, odnosno odluka koju je potrebno donijeti. Sami kriteriji mogu biti strukturirani na razne načine pa zato unutar glavnih kriterija može postojati i razina potkriterija. Alternative između kojih se bira sadrže sve kriterije u ovisnosti o vlastitim karakteristikama.

I kriteriji i alternative uspoređuju se prema Saatyjevoj skali (slika 5.) koja je prilagođena ljudskoj prirodi odlučivanja i prosuđivanja važnosti.



Slika 5. Saatyjeva skala (brojčana) [22]

Na slici 5. vidljivo je kako se međusobno i zasebno kriteriji i alternative uspoređuju prema važnosti na skali od 1 do 9, pri čemu je 1 najmanja važnost, a 9 najveća važnost.

Matematičkim postupkom baziranom na Booleanovoj algebri, s obzirom na dane usporedne vrijednosti dolazi se do optimalnog rješenja [21].

5.2.1. Prednosti i nedostaci AHP metode

AHP metoda ima niz prednosti kod odlučivanja.

- Metoda je izuzetno prilagođena korisniku kojem je omogućeno njeno jednostavno korištenje. Osim procjenjivanja važnosti različitih kriterija, moguća je usporedba različitih alternativa te provedba simulacija koja prikazuje promjene u izlaznim podacima izmjenom ulaznih podataka.
- Metoda je dokazana u praksi i primjenjuje se već dugi niz godina.
- Omogućena provjera konzistentnosti korisnika.
- AHP metoda omogućava usporedbu kvalitativnih i kvantitativnih kriterija pomoću apsolutne skale za mjerenje i na kraju procjenjivanje te uspoređivanje njihovih važnosti.
- Sami se kriteriji i alternative uspoređuju u parovima, što smanjuje mogućnost pogreške.
- Olakšan i ubrzan proces donošenja odluke, zbog čega se korisnik osjeća puno bolje.
- Stvoreni su uvjeti za timski rad. Time je u mogućnosti dogovoriti se oko prioriteta i ocjena raznih kriterija te svatko može unijeti svoju varijantu i obrazložiti svoje rezultate.
- Postoje programi koji su vrlo razvijeni i jednostavni za korištenje te omogućuju brzo i jednostavno donošenje odluke (kao npr. *Expert Choice*).
- Ušteda vremena i smanjenje troškova.

Prednosti AHP metode u nekim slučajevima postaju i nedostaci.

- Čovjek je taj koji donosi odluku o važnosti jednog kriterija ili alternative nasuprot drugoj. Teško je da točno i precizno „odvagnuti“ njenu prevlast ili podčinjenost. Na bodovnoj je skali od jedan do devet teško odabrati točan broj, odnosno, je li kriterij (alternativa) A pet ili četiri puta važnija od kriterija (alternative) B. Jedno od


ponuđenih rješenja dao je Hajkowicz (2000.) koji je u svojoj studiji koristio dvobodovnu ljestvicu što je olakšalo i skratilo cjelokupan proces donošenja odluke, što znači da su korisnici morali prosuditi samo je li kriterij (alternativa) više, manje ili jednako važan kao i drugi kriterij (alternativa).

- Kod kompleksnih zadataka postoji veliki broj kriterija i potkriterija pa struktura problema postaje sve kompleksnija, a broj parnih usporedba jako velik što produljuje proces donošenja odluke i otežava cjelokupan proces [21], [23], [24].

6. Određivanje redoslijeda operacija korištenjem AHP metode


6.1. Opis izratka

Redoslijed operacija bit će potrebno odrediti za izradu osovine koji zahtjeva operacije tokarenja i brušenja s pridruženim tehnološkim, pomoćnim (t_1) i pripremno-završnim vremenima (t_{pz}). Ukupno je potrebno odraditi deset operacija, što znači da postoji $10!$, odnosno 3 628 800 mogućih kombinacija (permutacije bez ponavljanja [25]). Grubo gledajući, postoji toliki broj mogućih redoslijeda operacija. Odmah na početku, postavlja se pitanje, kako se dolazi do upravo jedne kombinacije kao optimalne, ili, kako je moguće sva moguća rješenja svesti na nekoliko alternativnih opcija? Prva je stavka podjela na finu i grubu obradu. Ukupno je šest operacija grube obrade i četiri operacije fine obrade. Pritom se operacije fine obrade dijele na tokarenje i brušenje te sa samog tehnološkog aspekta jedino je izvedivo da operacije brušenja slijede nakon operacija finog tokarenja. Sada je situacija da su moguće $6!=720$ kombinacije grube obrade i po dvije kombinacije finog tokarenja i brušenja. Budući da je unaprijed određen međusobni redoslijed finih operacija, one daju dvije moguće alternative pa je tako ukupno moguće izvesti $720+2+2=724$ različitih redoslijeda operacija. Dodatno je ograničenje da bušenje provrta treba slijediti iza operacije čeonog tokarenja. Obe operacije su po dvije, stoga preostaje da je bitan redoslijed između četiri preostale operacije – uzdužnog i čeonog tokarenja. To su $4!=24$ moguće kombinacije, odnosno $24 +$ četiri kombinacije fine obrade i dvije kombinacije operacija bušenja, ukupno 30 operacija. Daljnji se tijekom smanjenja alternativa treba sagledati s tehničkog, tehnološkog i ekonomskog aspekta (ili dodatno, po želji korisnika), odnosno svih značajnih utjecaja na proces kako bi se od 30 operacija odabrao potreban redoslijed. Sve u svemu, s jednostavnim premisama s 3 628 80 se svelo na 30 mogućih redoslijeda operacija između kojih je potrebno odabrati najbolju [8].




Slika 6. CAD crtež osovine [26]

Za osovину su određene operacije koje je potrebno provesti, prikazane u nastavku.




Slika 7. Izrada površine 1 [26]

Površina 1, prikazana na slici 7. obradit će se tokarenjem, no budući da se tokarenjem može postići minimalna hrapavost 0,8 Ra, potrebno je obaviti i proces brušenja. Tokari se na 1,6 Ra, a zatim brušenjem 0,4 Ra.




Slika 8. Izrada površine 2 [26]

Površina prikazana na slici 8. obrađuje se tokarenjem uz zahtijevanu površinsku hrapavost 0,8 Ra.




Slika 9. Izrada površine 3 [26]

Površina prikazana na slici 9. obrađuje se tokarenjem na 0,8 Ra.



Slika 10. Izrada površine 4 [26]

Površinu prikazanu na slici 10. potrebno je tokariti na 1,6 Ra te naknadno brusiti na 0,4 Ra.



Slika 11. Izrada površine 5 [26]


Površina prikazana na slici 11 Slika 11. tokarit će se na 1,6 Ra i brusiti na 0,4 Ra.

Finalno, operacije koje je potrebno izvesti su:


- rezanje (piljenje sirovca na pili)
- tokarenje
- bušenje središnjih provrta
- brušenje potrebnih površina

Operacije će se obaviti na tri stroja - pili, cnc obradnom centru (tokarenje i bušenje) te na brusilici (prilog 1.).

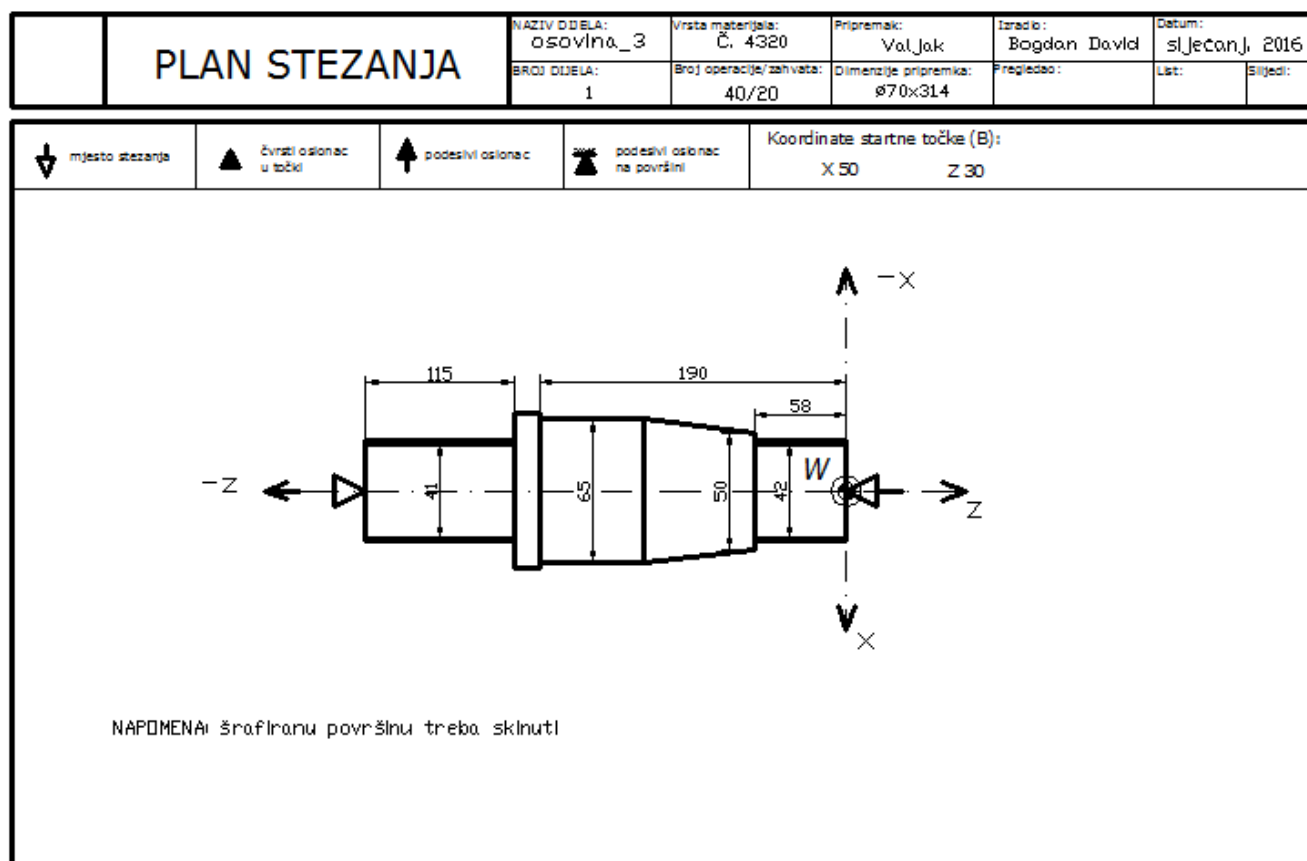
S obzirom na skupine operacija, dani su planovi stezanja, prikazani na slici 12., slici 13. i slici 14.



Slika 12. Plan stezanja 1 [26]



Slika 13. Plan stezanja 2 [26]



Slika 14. Plan stezanja 3 [26]

S obzirom na dane informacije, evaluacija će se provesti prema kriterijima naznačenima u poglavlju 6.2.

Podaci o vremenima obrade dani su u tablici 1.

Tehnološka operacija	Stroj	tPZ, min	tp, min	t1, s
STEZANJE 1	Obradni centar	30		
Tokarenje čcono 1			0,23	15
Tokarenje uzdužno 1			0,5	30
Tokarenje po konturi 1 (fino)			0,2	40
Bušenje središnjeg provrta 1			0,2	36
STEZANJE 2	Obradni centar	30		
Tokarenje čcono 2			0,23	15
Uzdužno tokarenje 2			0,5	45
Tokarenje po konturi 2 (fino)			0,2	50
Bušenje središnjeg provrta 2			0,2	36
STEZANJE 3	Brusilica	30		
Brušenje fi42k6			0,6	45
Brušenje fi41h7			0,6	50

Tablica 1. Vremena obrade [26]

Vremena obrade dijele se na pripremno-završno vrijeme (t_{pz}), pomoćno vrijeme (t_p) i tehnološko vrijeme (t_1). Navedene operacije su u postupku odlučivanja AHP metodom alternative, a model će se formirati tako da je najbolje rješenje operacija koja će se izvesti prva, a najmanje pogodno rješenje je operacija koja će se izvesti na samom kraju. Promjene stezanja utjecati će kod međusobne evaluacije alternativa, kod čega je, naravno, promjena načina stezanja nepovoljna opcija jer oduzima određeno vrijeme, što povećava troškove. Dodatni podatak važan za daljnji proces je cijena radnog sata stroja. Koriste se dva stroja – obradni centar i brusilica. Na obradnom se centru obavljaju operacije tokarenja i bušenja, a na brusilici brušenja. Uzeto je da je radnog sata obradnog centra je 15 eura, a brusilice 12 eura¹.

Grubom je analizom na samom početku moguće zaključiti da operacije brušenja svakako moraju slijediti ostale operacije, jednako kao i operacije finog tokarenja po konturi koje moraju slijediti nakon operacija grubog tokarenja. Također, operacije bušenja provrta moraju slijediti nakon operacije čeonog tokarenja jer je to tehnički zahtjev površine.

¹ Cijene radnog sata formirane su kao školski primjer na osnovu prosječnih cijena radnih sati strojeva.

6.2. Kriteriji i opis kriterija

Brainstormingom eksperata u području planiranja procesa i proizvodnje dobiveni su sljedeći kriteriji koji su temeljni dio strukture problema u AHP metodi.

TEHNOLOŠKI KRITERIJI

- broj operacija
- broj izmjena alata
- tehnološko vrijeme (ukupno)
- pomoćno vrijeme (ukupno)
- trošenje alata/trajanje oštice
- broj stezanja
- vrsta stezanja
- brzina rezanja
- SHIP
- kritična brzina vrtnje s posljedicama

EKONOMSKI KRITERIJI

- produktivnost/sat
- cijena alata
- cijena radnog sata
- odražavanje cijene procesa na cijenu proizvoda
- cijena radnika (direktnog)

KRITERIJI IZRATKA

- prioritet procesa
- kvaliteta – odražavanje procesa na kvalitetu proizvoda
- površinska zaštita
- materijal
- veličina obradne površine
- mogućnost pogreške

- tolerancija
- veličina kvalitete površine
- funkcionalnost izratka (strukturna svojstva primarnog procesa, očekivana naprezanja, sile tijekom rada)

EKOLOŠKI KRITERIJI

- energetska učinkovitost – potrošnja struje/vode – po satu
- toksičnost SHIP-a, odvodnja
- količina odvojenih čestica

ERGONOMSKI KRITERIJI

- prisutstvo radnika
- dostupnost obratka, potreba manipulacije
- mogućnosti manipulacije obratka
- upravljivost cjelokupnim procesom

KRITERIJI PROCESA

- mogućnost automatizacije
- broj strojeva koji sudjeluju u procesu
- mogućnosti modifikacije
- unutarnji transport
- organizacija

Kriteriji su strukturirani u nekoliko skupina – kriteriji vezani za tehnološki proces, izradak, ekonomske činjenice, ekologiju i ergonomiju.

Oni se najgrublje mogu podijeliti na kvalitativne i kvantitativne kriterije. Kvantitativni kriteriji su oni koji se mogu kvantificirati, kako i samo ime kaže, odnosno koji sadrže točnu brojčanu vrijednost na temelju koje se vrši usporedba, proračun važnosti jednog u odnosu na drugi. Tu su npr. broj operacija, broj izmjena alata, tehnološko vrijeme, pomoćno vrijeme...

Za kvalitativne kriterije ne postoje točni podaci na temelju kojih bi se korektno mogle usporediti određene činjenice o kriterijima i alternativama, stoga se oni prosuđuju na temelju

slobodne procjene stručnjaka, temelje na njegovim osobnim znanjem i dosadašnjim iskustvom. Kvalitativni i kvantitativni kriteriji posebno su izdvojeni i prikazani u tablici 2.

	Kvalitativni kriteriji	Kvantitativni kriteriji
Tehnološki kriteriji		
		broj operacija
		broj izmjena alata
		tehnološko vrijeme
		pomoćno vrijeme
	trošenje alata/trajanje oštrice	
	vrsta stezanja	broj stezanja
	SHIP	brzina rezanja
	kritična brzina vrtnje	
Ekonomski kriteriji		
	produktivnost/sat	
		vrijeme izrade po operaciji
		cijena alata
		cijena radnog sata
	odražavanje cijena na cijenu proizvoda	
		cijena radnika (direktnog)
Kriteriji izratka		
	prioritet procesa	
	kvaliteta - odražavanje procesa na kvalitetu proizvoda	
	površinska zaštita	
	materijal	
	veličina obradne površine	
	moгуćnost pogreške	
	tolerancja	
	veličina kvalitete površine	
	funkcionalnost izratka	
Ekološki kriteriji		
	energetska učinkovitost	
	toksičnost SHIP-a	
	količina odvojenih čestica	

Ergonomski kriteriji

	potreban čovjek
	dostupnost obratka, potreba
	manipulacije
mogućnosti manipulacije	
obratka	
upravljivost cjelokupnim	
procesom	

Kriteriji procesa

mogućnost automatizacije	
	broj strojeva koji sudjeluju u procesu
mogućnosti modifikacije	
unutarnji transport	
organizacija	

Tablica 2. Kvalitativni/kvantitativni kriteriji

Iz tablice 2. vidljivo je kako je puno više kvalitativnih kriterija od kvantitativnih što u globalu i nije najbolje rješenje, jer je ljudski faktor u tim situacijama presudan. Upravo će se zbog toga koristiti naputci za umanjeње utjecaja subjektivnosti pri korištenju AHP metode.

6.3. Prijedlozi za minimizaciju utjecaja subjektivnosti u AHP procesu

Primjenom AHP metode kao takve, uočeni su nedostaci u svakom njenom koraku [21]. Na samom je početku potrebno definirati kriterije na temelju kojih će se donijeti odluka. Ne postoji objektivan način za definiranje kriterija već to rade eksperti gdje njihova subjektivnost i mogućnost ljudske pogreške dolazi do izražaja. To je posljedica razine znanja, ograničenja generalizacije i načina prosudbe. Sličan problem postoji i kod definiranja alternativa između kojih će se obavljati konačni odabir. Kriterije je zatim, kao i alternative, potrebno međusobno vrednovati, pomoću važnosti kriterija, koji je kriterij važniji, a koji je manje važan. Pitanje je, kako točno znati koji je kriterij važniji od drugog i koliko?

Kod vrednovanja alternativa, potrebno je procijeniti koja je alternativa važnija u odnosu na drugu u zadanom kriteriju. Kriteriji mogu biti kvalitativni i kvantitativni. Kod kvantitativnih kriterija nema diskusije, za svaku alternativu postoji egzaktni brojčani iznos koji je prethodno dobiven ili mjerenjem ili nekim drugim metodama i on je kao takav valjan i matematički ga model dobro obrađuje. Na kraju daje očekivani i egzaktni rezultat, odnosno, očekivanu odluku. No, vrlo je čest slučaj da, pogotovo, složeni kriteriji nisu kvantitativni već su isključivo kvalitativni i nije moguće objektivno odrediti je li neka alternativa (i koliko je)

bolja u odnosu na drugu. To može biti i posljedica ili presloženih matematičkih modela ili nemogućnosti/neposjedovanja mjerne opreme, senzora, problema prikupljanja i obrade podataka i sl.


6.3.1. Strukturiranje brainstormingom

Prvi korak, strukturiranje kriterija i problema odvija se procesom *brainstorminga*. To je proces kod kojeg tim eksperata nasumično nabacuje ideje, ali takav način ima mnogo nedostataka.

Umjesto klasičnog brainstorminga predlaže se korištenje brainstorminga nominalnih grupa [27] u kojem individualci sami “nabacuju” ideje, tj. kriterije. Istraživanja su pokazala kako su pojedinci u ovom slučaju produktivniji od grupe te nisu pod utjecajem ostalih što može utjecati na formiranje njihovog mišljenja na licu mjesta [28]. Nakon generativne faze, evaluacijska se faza *brainstorminga* trebala bi se odvijati u timu te bi eksperti mogli komentirati dobivena rješenja, odnosno predložene ideje. Ovdje je važna uloga moderatora koji mora, između ostalog, formirati ovu fazu na najproduktivniji mogući način te da utjecaj pojedinca ne pokvari ideje ili rad ostalih članova tima. Tada je moguće formirati nekoliko strukturnih modela kriterija i provesti tajno glasanje u kojem bi se odabrao jedan model kao konačni. Pogodno je da je glasanje tajno kako prisustvo određenih članova tima ne bi utjecalo na mišljenje, odnosno glasove drugih članova tima. Rezultati glasanja moraju biti većinski, a točan udio ovisi o složenosti i važnosti pojedine teme, o čemu ponovno odlučuje moderator.

6.3.2. Struktura i broj kriterija


AHP metoda dozvoljava da se kriteriji strukturiraju na više razina i na različite načine. Postoji razina kriterija i potkriterija (slika 15.) [21].



Slika 15. Struktura AHP modela [21].

U svakoj se grupi potkriterija, nakon njihovog rangiranja po važnosti, provodi matematička AHP metoda čime se dobiva važnost i numerički podatak o prednosti jednog kriterija naspram drugom unutar jedne grupe potkriterija. Zatim se po pravilu agregacije [29] te važnosti zbrajaju kako bi se dobio konačan poredak važnosti kriterija kao cjelovite strukture.


Ukoliko je problem složen te se do konačnog cilja dolazi preko velikog broja kriterija, tada je model potrebno strukturirati na što jednostavniji način. Preporuka je da svaki kriterij ima *jednak broj razina potkriterija* kako bi cijela stvar što pravilnije mogla matematički izračunati. Ukoliko među podkriterijima postoje dodatni potkriteriji (slika 16.), teorijski je dopušteno i moguće je i na takav način strukturirati model, no zbog jednostavnosti i veće objektivnosti u samom početku, važno je da je struktura jasnija i jednostavnija (slika 17.). Takva struktura omogućava lakše međusobno vrednovanje kriterija te na kraju bolju i točniju konačnu odluku.



Slika 16. Loše strukturirani kriteriji

Na slici 16. prikazan je primjer loše strukturiranih kriterija koji su često proizvod pokušaja obuhvaćanja velikog broja ideja generiranih procesom *brainstorminga*. U ovakvim je situacijama teorijski moguće provesti matematički postupak i doći do konačno cilja, no upitna

je njegova valjanost. Usred postupka agregacije, nepravilno strukturirani potkriteriji, koji mogu biti jako važni, gube na svojoj važnosti i smanjuje se njihov udio u konačnom cilju.



Slika 17. Primjer dobro strukturiranih kriterija


Iz slike 17. vidljivo je kako su svaka razina kriterija ima jednak broj potkriterija, zbog čega je olakšan matematički izračun. Također, sam model je pregledniji i kriterije je lakše hijerarhijski poredati te vrednovati njihovu međusobnu važnost.

6.3.3. Problem kvalitativnih kriterija

Sljedeći je korak međusobno vrednovanje alternativa. Alternative mogu biti veoma različite, a informacije o njima većinom se dobivaju od proizvođača ili od trgovca, ukoliko se radi o fizičkim proizvodima. Ti su podaci dobiveni proračunima i mjerenjima i kao takvi su ispravni i relevantni za model. No, nisu svi podaci komercijalno dostupni ili je do njih jednostavno jako teško doći. Ukoliko postoji želja da se model napravi što detaljnije i da odluka bude što bolja, potrebno je uključiti i takve podatke u igru. Taj se slučaj javlja kod kvalitativnih kriterija. To su kriteriji kod kojih se alternative vrednuju prema subjektivnoj procjeni korisnika, člana tima, primjerice razina zadovoljstva korisnika. Kod kvantitativnih kriterija postoji točna/procijenjena brojčana vrijednost koja se na pravilan način matematički generira u modelu, no kvalitativni kriteriji podliježu ljudskoj subjektivnosti koju je potrebno eliminirati ili ju smanjiti što je više moguće.

Kvalitativne kriterije potrebno je najprije izdvojiti od ostalih i pogledati gdje se nalaze i kakva je njihova važnost naspram drugim kriterijima. Ukoliko je njihova važnost jako mala onda i relativno kriva usporedba alternativa neće imati prevelikog utjecaja na finalni rezultat. No, kod vrlo važnih odluka mora se na i ovakve stvari obratiti pažnja. Ukoliko je njihova važnost velika i nalaze se u grupi gdje je nekoliko kvalitativnih kriterija, potrebno je obratiti posebnu pozornost jer se greške subjektivnosti u tom slučaju akumuliraju i utječu na konačnu odluku.

Prvi korak je istražiti kriterije, koje su njihove karakteristike, njihov opis i značaj općenito. Tada je potrebno odrediti povezanost tih kriterija s ostalim, kvantitativnim kriterijima. Također, ukoliko su ti kriteriji povezani s nekom karakteristikom koja se ne nalazi u modelu kao kriterij, a kvantitativnog je karaktera, potrebno je također razmotriti tu situaciju. Alternative je tada potrebno hijerarhijski poredati s obzirom na kriterije s kojima su povezani. Kada se dobije hijerarhija za svaki srodan kvantitativan kriterij, potrebno je ponovno generirati konačan poredak pomoću analitičkog programa (slika 18.) kao što je npr. *Microsoft Excel* [30].



Slika 18. Ilustracija postupka određivanja međusobne važnosti alternativa

U *Excelu* je to moguće pomoću funkcije za određivanje poretka redova ili stupaca (ovisno kako je korisnik definirao dokument) prema vrijednosti, od najviše prema najmanjoj ili obrnuto. Također, kao dodatnu provjeru, moguće je da tim eksperata na temelju zadanih podataka napravi i intuitivnu procjenu pa se to uključi u konačan poredak.

Na taj su se način kvalitativni kriteriji kvantificirali i smanjen je utjecaj subjektivnosti u cijelom modelu što dovodi do pravilne konačne odluke.

6.3.4. Problem broja alternativa

Kada se pri donošenju odluke koristi određeni softver koji posjeduje matematički postupak te tako olakšava proces donošenja odluke, olakšano je i odabiranje između većeg broja alternativa. Naime, ukoliko se odlučivanje provodi bez određenog matematičkog postupka, utjecaj čovjeka je presudan, a čovjek nije sposoban rangirati više alternativa. „Više“ se različito definira za različite osobe, no u globalu je sigurno da ljudi nisu sposobni na temelju većeg broja kriterija, bili oni kvalitativni ili kvantitativni, ocijeniti koja je alternativa najbolja, a time donijeti i egzaktnu odluku [31].

Ovdje alati za pomoć pri donošenju odluke posebno dolaze do izražaja jer omogućuju na brz i jednostavan način obuhvaćanje većeg broja alternativa, a time se povećava vjerojatnost dobrog ishoda, odnosno povoljne odluke.

Kod AHP metode i programa *Expert Choice* izrazito je jednostavno dodavati, brisati ili mijenjati alternative. No, problem se javlja kod njihovog vrednovanja, odnosno parnih usporedbi. Ukoliko je broj *alternativa veći od deset*, proces postaje dugotrajan i mukotrpan, pogotovo ako je riječ o kvalitativnim kriterijima.

Postoje dva rješenja ovog problema – prvo se odnosi na strukturiranje i odabir kriterija, drugi se odnosi na broj alternativa.


Ukoliko se odluči da broj kriterija ostane velik, kriteriji se trebaju prilagoditi takvoj situaciji. Kako bi model bio valjan, potrebno je odabirati isključivo kvantitativne kriterije čime bi se u potpunosti iskoristila prednost korištenja matematičkog postupka implementiranog u program. Isti model treba biti jednostavno strukturiran, čime je olakšan unos podataka.

Najbolja opcija je da u modelu nema kvalitativnih kriterija jer, ukoliko nema kvantifikacije cijeli proces postaje izrazito dugotrajan i mukotrpan, a čovjek nije sposoban prosuditi koja je alternativa važnija od druge zbog njihovog velikog broja. Kvantifikacija je u ovom slučaju dobar odabir, no samo ukoliko su kvalitativni kriteriji nužni. Njome se produljuje cjelokupni postupak i moguće je da dođe do zamora korisnika.

Stoga je najbolje da broj alternativa ni u kojem slučaju ne prelazi deset, dok bi se pet alternativa navelo kao optimalno.

7. OBRADA PODATAKA I REZULTATI

Ulazni će se podaci obraditi pomoću softvera *Expert Choice* u koji je implementirana AHP metoda. To je softver koji je prilično jednostavan za korištenje, stabilan je i pregledan što omogućuje lak i relativno brz dolazak do finalnog cilja, u ovom slučaju, redoslijeda operacija. Sukladno iznesenim podacima, kriteriji i alternative su međusobno uspoređeni i dobiveni su rezultati prikazani na slici 19.



Slika 19. Rezultati AHP metode

Na slici 19. prikazani su dobiveni rezultati u primarnom slučaju. Kao najbolja opcija predlaže se Tokarenje čeonno 1, nakon čega slijedi Tokarenje čeonno 2. Rezultate je potrebno kritički posmatrati i istaknuti kako su operacije brušenja ispred operacija tokarenja. Također, operacije finog tokarenja, predložene su da se izvedu prije operacije uzdužnog tokarenja, što tehnički nije moguće izvesti. Potrebno je uvesti modifikaciju modela.


7.1. Modifikacije procesa – razni scenariji:

U nastavku je provedena analiza osjetljivosti na modelu, sukladno mogućim situacijama koje bi se mogle dogoditi u svakodnevnoj poslovnoj situaciji.


7.1.1. Fina/gruba obrada

Budući da se u prethodnom primjeru pojavio problem s finom i grubom obradom, potrebno je uvesti eliminacijski kriterij koji bi odvojio u posebno razvrstao fine i grube obrade, odnosno obrade koje je nužno izvesti na samom kraju. Uveden je novi kriterij FINA/GRUBA obrada

kojem je dan veliki utjecaj na cjelokupan proces, no unatoč tome, on osim eliminacijskog karaktera, nema drugog utjecaja na redoslijed operacija, jer je omjer utjecaja ostalih kriterija ostao isti. Rezultati su prikazani na slici 20. i slici 21.



Slika 20. Rezultati s novim kriterijem „Fina/gruba obrada“



Slika 21. Rezultati i utjecaj kriterija s novim kriterijem „Fina/gruba obrada“

Vidljiv je veliki utjecaj novog kriterija, ali i poredak koji je sada logičan i tehnički moguć.


Poredak operacija predložen u ovom slučaju je sljedeći:

1. Tokarenje čeono 1
2. Tokarenje čeono 2
3. Tokarenje uzdužno 1
4. Bušenje središnjeg provrta 1
5. Bušenje središnjeg provrta 2
6. Tokarenje uzdužno 2
7. Tokarenje po konturi 2 (fino)
8. Tokarenje po konturi 1 (fino)
9. Brušenje $\phi 42$
10. Brušenje $\phi 41$

Redoslijed operacija u ovom slučaju je zanimljiv jer nalaže promjenu vrste stezanja nekoliko puta tijekom procesa. Razlog tome je slab utjecaj dotičnog kriterija na cjelokupan proces, pa se on tako ne odražava na finalni rezultat te se promjena stezanja smatra povoljnom i pogodnom opcijom u ovom slučaju, tj. u ovoj strukturi problema za koju se pretpostavlja da je kreirana od strane skupine eksperata. Budući da se radi o obradnom centru koji je u mogućnosti automatski promijeniti vrstu stezanja, vrijeme potrebno za to kao kvalitativan kriterij nije bilo presudno stoga se može zaključiti da je ovo rješenje usvojivo u određenoj situaciji.

7.1.2. *Kraće vrijeme izrade – pripremno-završno i pomoćno*

Procesi se najčešće unapređuju smanjenjem vremena nepotrebnih aktivnosti, u ovom slučaju bi se to moglo primijeniti na pomoćno vrijeme i tehnološko vrijeme koje je određenim radnjama moguće smanjiti – npr. ugradnjom automatskog dodavača obratka ili korištenjem robota. U tom se slučaju, osim smanjenja pomoćnog vremena povećava produktivnost čime bi se u konačnici mogla smanjiti i cijena radnog sata. Također je kraće ukupno vrijeme izrade pa postoji mogućnost povećanja energetske učinkovitosti. Na tim su kriterijima urađene modifikacije i dobiveni su sljedeći rezultati. U ovom će slučaju biti smanjeno vrijeme operacija tokarenja za 20%.



Slika 22. Rezultati – smanjeno tehnološko vrijeme


Vidljivo je kako se, unatoč modifikaciji, rezultati nisu promijenili te da je redoslijed ostao isti. Smanjeno je tehnološko vrijeme, cijena radnog sata i povećana je produktivnost operacija tokarenja, no promjene se nisu dogodile, ostali kriteriji imaju značajniji utjecaj na cjelokupnu situaciju. Također, kvantitativne promjene u cijeni nisu drastične pa je i to razlog izostanka promjena.

7.1.3. *Paletni sustav i napredne vrste stezanja*

Primjenom paletnog sustava, jednako kao i kod naprednih vrsta stezanja, smanjeno je tehnološko vrijeme, odnosno pomoćno koje je u ovom slučaju zbrojeno zajedno s tehnološkim. Smanjuje se i pripremno-završno vrijeme te se povećava produktivnost.

Također, povećat će se utjecaj kriterija vezanog za vrstu stezanja, sadržanog u glavnom kriteriju – tehnološki kriteriji. Modifikacija će se nadograditi na slučaj u poglavlju 7.1.2.

Dobiveni rezultati prikazani su na slici 23.




Slika 23. Rezultati – povećan utjecaj tehnoloških kriterija

Nakon provedene analize osjetljivosti u kojoj se povećao utjecaj tehnoloških kriterija u kojima je pretpostavka unapređenje sustava stezanja, nisu se dogodile promjene, samo se smanjio omjer razlike između operacija fine i grube obrade, što je logično jer se povećanjem udjela jednog kriterija smanjio udio drugog važnog kriterija, a to je kriterij fine/grube obrade.

7.1.4. Manja cijena radnog sata

Ukoliko se promijeni cijena radnog sata, a ostale komponente ostanu iste, dobiveni su sljedeći rezultati.



Slika 24. Rezultati – manja cijena radnog sata

Kao i u prethodnom slučaju, nisu nastupile promjene, te je poredak ostao isti. Kao finalni i optimalni redoslijed operacija, s obzirom na strukturu problema usvaja se sljedeći:

1. Tokarenje čeonno 1
2. Tokarenje čeonno 2
3. Tokarenje uzdužno 1
4. Bušenje središnjeg provrta 1
5. Bušenje središnjeg provrta 2
6. Tokarenje uzdužno 2
7. Tokarenje po konturi 2 (fino)
8. Tokarenje po konturi 1 (fino)
9. Brušenje fi42
10. Brušenje fi41

7.2. Evaluacija rezultata

Nakon dobivenog redoslijeda operacija, koji je predstavljen kao optimalan, potreban je kritički pogled na situaciju i evaluacija je li taj redoslijed uistinu optimalan ili je potrebna modifikacija procesa ili čak odbacivanje korištenja čitavog postupka. Metodom je uspješno moguće odvojiti operacija finih od operacija grubih obrada. To je potrebno imati na umu čitavo vrijeme rada sa softverom *Expert Choice* i prema tome dodjeljivati ocjene u

međusobnoj usporedbi alternativa, ali i dati veliku važnost kriteriju fina/gruba obrada. Nadalje, zbog same strukture kriterija i njihove važnosti, uz karakteristike procesa, metodom je uspješno izvedeno da operacije bušenja provrta slijede iza operacija čeonog tokarenja. No, ako se problem sagleda u dva stezanja, vrlo je zanimljiva, a pomalo i nezgodna činjenica da se usred operacija nekoliko puta izmjenjuje način stezanja. S jedne strane bi se to moglo protumačiti kao gubitak vremena jer je potrebno određeno pomoćno vrijeme svaki puta iza operacije kako bi došlo do promjene stezanja. Pitanje je i dostupne opreme – ako je promjena stezanja kratka i automatizirana, to možda i ne predstavlja problem, no ako je potrebno zaustaviti čitav proces kako bi se promijenilo stezanje, to nikako ne ide u korist. Razlog takvim rezultatima je detaljan model koji uzima u obzir mnoge različite kriterije i, premda njihov utjecaj možda veliki, utjecaj se agregira pa tako u finalnom rezultatu može doći do nepredviđenih situacija. Budući da dan redoslijed operacija nije tehnički nemoguć, on bi se mogao shvatiti kao optimalan, s obzirom na strukturu problema. To se može shvatiti kao nedostatak, ali kao i prednost cjelokupnog postupka jer dopušta korisniku da kreira model prema individualnim potrebama čime će dobiti rezultate koji odgovaraju točno određenoj situaciji.

8. ZAKLJUČAK

Dio životnog ciklusa proizvoda, između dizajna i razvoja proizvoda te same fizičke proizvodnje sastoji se od četiri koraka. Prvi je odabir primarnog procesa, drugi je odabir stroja i alata, treći je odabir parametara, a četvrti je odabir redoslijeda operacija. Kod odabira primarnog procesa postoje uvažene metode (Halevi, ASM), jednako kao i kod odabira alata i strojeva na koji se nadovezuje odabir parametara procesa. Za redoslijed operacija ne postoji točno definiran postupak koji bi omogućio jednostavno određenje optimalnog redoslijeda operacija. Određivanje redoslijeda operacije moguće je sagledati kao proces donošenja odluka, a jedan od širokoprimjenjivih alata za donošenje odluka je AHP metoda implementirana u program *Expert Choice*. Korištenjem ove metode na slučaju izrade vratila koje zahtjeva operacije tokarenja, bušenja i brušenja došlo se do zaključka kako je ovu metodu moguće koristiti u slučajevima određivanja redoslijeda operacija. Metodu je jednostavno koristiti i omogućuje provedbe analiza osjetljivosti, no primijećeni su određeni nedostaci. Glavni korak u cjelokupnom procesu je strukturiranje problema na koji naveliko utječe subjektivnost eksperata koju je na neki način moguće ukloniti. Također, ne postoji mjerilo koje bi dokazalo da su upravo dani rezultati optimalni te je, kao dio budućeg istraživanja, potrebno istražiti mogućnost implementacije određene vrste umjetne inteligencije u čitav proces koja bi prepoznala moguće tehničke nemogućnosti koje se javljaju koje AHP metoda nije u mogućnosti prepoznati jer se radi isključivo o matematičkoj metodi koja u sebi nema implementirano znanje vezano za tehničko područje izrade proizvoda. Unatoč korištenim metodama za djelomično umanjeње subjektivnosti, još je uvijek subjektivnost bitan faktor u cjelokupnom procesu. Kao najpovoljnija opcija predlaže se korištenje isključivo kvantitativnih kriterija. Također, AHP metoda bi se trebala ispitati na kompleksnijem dijelu koji sadrži više operacija čiji redoslijed, na neki način, nije već unaprijed po svojoj prirodi definiran. S druge strane, tu se postavlja problem korištenja dostupnog programa čije korištenje postaje otežano dodatkom većeg broja alternativa i kriterija.

Finalno, AHP metoda dobar je alat za određivanje redoslijeda operacija, no potrebna su daljnja istraživanja i unapređenja čitavog sustava kako bi se mogla koristiti u svakoj situaciji u realnoj proizvodnji.

LITERATURA

- [1] Roller, D.: An approach to computer-aided parametric design. *Computer-Aided Design*, Volume 23, Issue 5, lipanj 1991., str. 385–391
- [2] Chang, T.; Wysk, R.; Wang, H.: *Computer Aided Manufacturing*. Prentice-Hall Inc. New Jersey, 1998.
- [3] Engelke, William D.: *How to Integrate CAD/CAM Systems: Management and Technology*, str. 237-238. CRC press, 1987. Decker, K. H.: *Elementi strojeva*, Tehnička knjiga Zagreb, 1975.
- [4] Hazarika, M.; Dixit, U.: *Setup Planning for Machining*. Springer, 2015.
- [5] *Product Lifecycle Management 21st century paradigm for Product Realisation*, Springer 2011.
- [6] Pulak, M.: *Computer Aided Process Planning*. <http://www.docslides.com/calandra-battersby/computer-aided-process-computer> (2016.)
- [7] Lukić, D.; Milošević, M.; Velimir, T.: *Integrirani CAPP sistemi i tehnološka vaza podataka (Modul Integrirani CAPP sistemi)*. Fakultet tehničkih nauka, Univerzitet u Novom Sadu. Novi Sad, 2013.
- [8] Ćosić, P.: *Projektiranje tehnoloških procesa*. Predavanje. Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu. Zagreb, 2013.
- [9] Crow, K.: *Strategy, Organization, Process, Methodologies, Technology*. NPD Solutions, SAD, 1992.
- [10] Monka, P.; Monkova, K.: *Individual Application System for Computer Aided Process Planning*. *Proceedings of the World Congress on Engineering*, vol 3., London, 2012.
- [11] Xiankui, W.; Chengying, L.: *THCAPP: Computer Aided Process Planning System in an Integrated Environment*. *Tsinghua Science and Technology*. Vol. 1, br. 2, lipanj 1996.
- [12] Kang, S.; Park, D.: *Application of computer-aided process planning system for non-axisymmetric deep drawing products*. *Journal of Materials Processing Technology*. Vol. 124, br. 1-2, lipanj 2002., str. 36-48.
- [13] Ahman, N.; Haque, A.; Hasin, A.: *Current Trend in Computer Aided Process Planning*. *Proceedings of the 7th Annual Paper Meet and 2nd International Conference*. The Institution of Engineering. Br. 10, str. 81-92. Bangladeš, listopad, 2001.
- [14] Halevi, G.; Weill, R.: *Principles of Process Planning*. Springer, 1995.

- [15] Scallan, P.: Process Planning: The design/manufacture interface. Butterworth-Heinemann, Elsevier, 2003.
- [16] Gačnik, V., Vodenik, F., Projektiranje tehnoloških procesa, Tehnička knjiga.
- [17] Gologlu, C.: A constraint-based operation sequencing for a knowledge-based process planning. Journal of Intelligent Manufacturing, br. 15, 2004., str. 463-470.
- [18] Kafashi, S.: Integrated setup planning and operation sequencing (ISOS) using genetic algorithm. International Journal of Advanced Manufacturing Technologies. Springer, 2011.
- [19] Nallakumarasamy, G.; Srinivasan, P.; Venkatesh Raja, K.; Malayalamurthi, R.: Optimization of operation sequencing in CAPP using simulated annealing technique (SAT). International Journal of Advanced Manufacturing Technologies. Br. 54, 2011. Str. 721-728.
- [20] Expert Choice, <http://expertchoice.com/> (6.1.2015.)
- [21] Saaty, Thomas: Decision making with the analytic hierarchy process. Int.J. Services Sciences, Vol. 1, No. 1, 2008.
- [22] Expert Choice 11.5. programška podrška korisnicima
- [23] Trstenjak, M.: Završni rad. FSB, Zagreb, 2014.
- [24] Begičević, N.: Doktorska dizertacija: Višekriterijalni modeli odlučivanja u strateškom planiraju uvođenja e-učenja. FOI. Varaždin, 2008.
- [25] Kovač-Striko, E.: Vjerojatnost i statistika. FPZ, 2005.
- [26] Bogdan, D.: Projektni zadatak - Osovina. Tehnološka priprema proizvodnje, Sveučilište sjever, 2016.
- [27] Ziegler, R.; Diehl, M.; Zijlstra, G.: Idea Production in Nominal and Virtual Groups: Does Computer-Mediated Communication Improve Group Brainstorming?, Group Processes Intergroup Relations April 2000 vol. 3 no. 2 141-158
- [28] Fabac, R.; Stepanić, J.: With & Within Complex Systems, Business Systems Laboratory, 2014.
- [29] Foreman, E.: Aggregating individual judgments and priorities with the analytic hierarchy process. European Journal of Operational Research. Vol. 108, br. 1, 1. srpanj 1998, str. 165.-169
- [30] MacDonald, M.: Excel 2013: The Missing Manual. O'Reilly Media, 2013.
- [31] Sikavica, P.; Hunjak, T.; Begičević Redep, N.; Hernaus, T.: Poslovno odlučivanje. Školska knjiga. Zagreb, 2014.

PRILOZI

I. Odabir primarnog procesa

Prilog 1 – odabir primarnog procesa

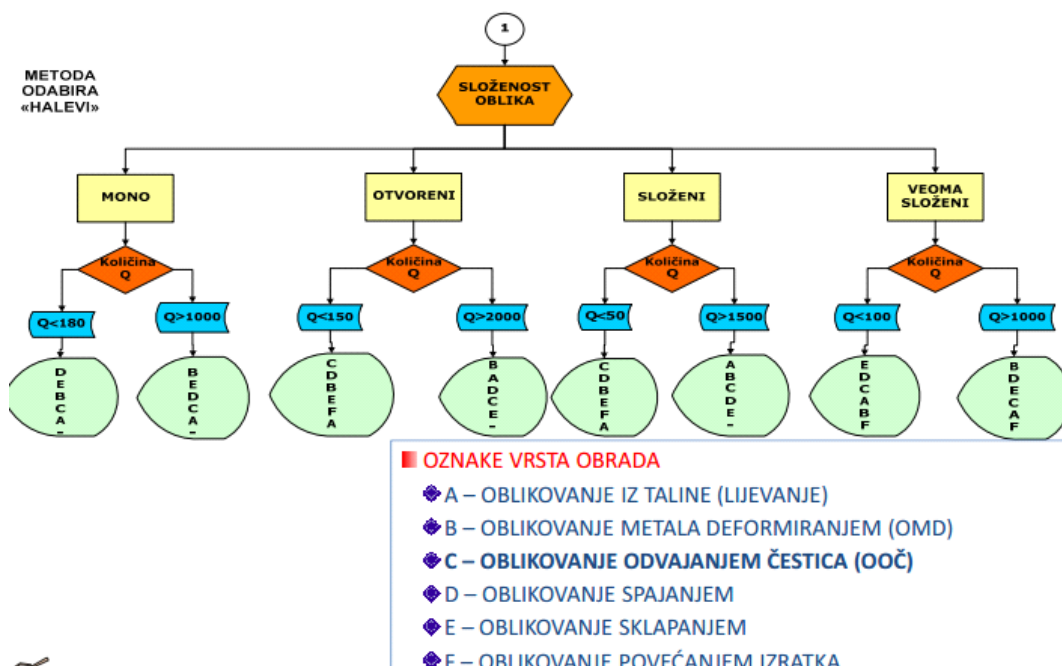
Odabir primarnog procesa prema Haleviju

Metodom prema Haleviju [14], u nastavku je opisan odabir primarnog procesa za proizvodnju osovine u količini od 150 komada.

KLASIFIKACIJA SLOŽENOSTI OBLIKA - HALEVI				
R. broj	VRSTA OBLIKA	SKICA OBLIKA IZRATKA		
1	MONO (konstantan presjek duž glavnog oblika)			
2	OTVOREN (simetričan oblik, ali promjenljivog presjeka)			
3	SLOŽENI (otvoreni oblik s bočnim značajkama)			
4	VRLO SLOŽENI (svi ostali oblici)			

Slika 25. Klasifikacija složenosti oblika po Haleviju [14]

Iz slike 25, utvrđeno je da je osovina otvorenog oblika jer ima simetričan oblik, ali promijenjivi presjek.



Slika 26. Odabir vrste oblikovanja prema Haleviju [14]

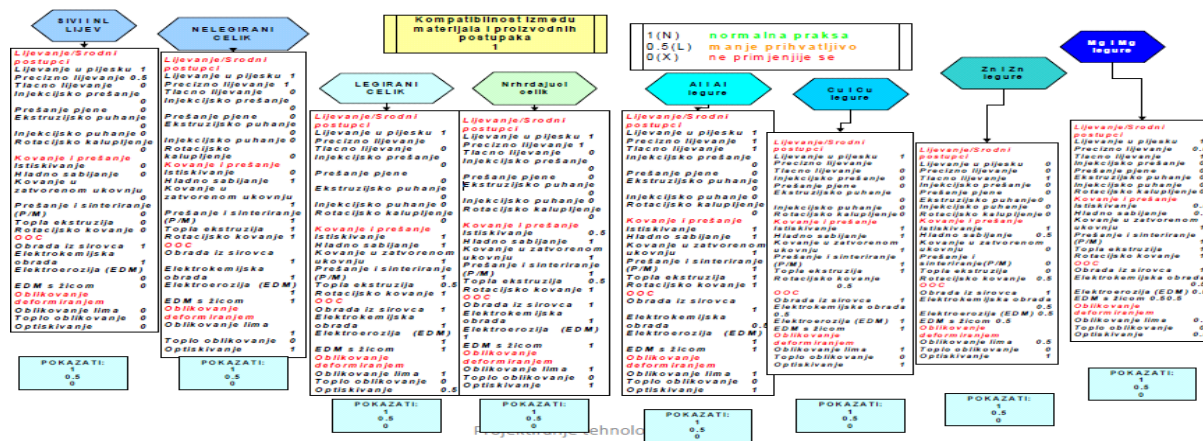
Na temelju zadane količine od 150 komada za utvrđeni otvoreni oblik i za $Q < 150$ (Slika 26.) odabire se obrada odvajanjem čestica kao primarni proces obrade.

Odabir primarnog procesa po ASM-u

	0 JEDNOLIK PRESJEK	1 PROMJENA NA KRAJU	2 PROMJENA NA SREDINI	3 ROSTORNA KRIVINA	4 ZATVOREN JEDAN KRAJ	5 ZATVORENA OBA KRAJA	6 POPREČNI ELEMENT	7 SLOŽENI OBLIK
OKRUGLI (R)					X	X		
PRAVOKUTNI (B)					X	X		
PRESJEK OTVOREN (S); POLUZATVOREN (SS)								
CIJEV (T)								
RAVNO (F)								
SFERNI (SF)	X		X	X	X	X		X

Slika 27. Klasifikacija oblika po ASM-u [13]

Prema ASM-u osovina je okruglog složenog oblika (slika 27.) [13].



Slika 28. ASM – kompatibilnost materijala i postupaka [13]

Vidljivo je (slika 28.) da ima više postupaka koji su kompatibilni prisutnim legiranim čelikom Č4320 (16MnCr5). Ali uzima se u obzir samo kovanje i obrada odvajanjem čestica zbog složenog oblika i njegove funkcionalnosti.

Moguće nedoumice

Ako bi se obradak izrađivao kovanjem svejedno bi trebala još i dodatna obrada odvajanjem čestica zbog zahtjeva hrapavosti površine i tolerancija. Treba još uzeti u obzir da je alat za kovanje poprilično skup, a radi se o maloj seriji proizvoda. Uzimajući sve činjenice u obzir, odbacuje se obrada kovanjem.

Konačni odabir

Odabrani primarni proces je obrada odvajanjem čestica. Odabire se zbog zahtjeva hrapavosti površina i dosjeda. Također je na odabir utjecao i broj komada (150) što je relativno mala serija.

Odabir osnovnih operacija

Pregledom dobivenog nacрта, te uzimanjem u obzir tolerancije i hrapavosti površina, valjana šipka promjera 70 mm uzet će se kao sirovac za daljnju obradu. Uzimajući u obzir da je promatrani predmet kružno simetričan, iz Slika 29., vidljivo je koje od operacija su moguće.

	Proces	Srednje odstupanje profila R_a (μm)	
		(min)	(max)
Kružno simetrični dijelovi	Tokarenje	0.8	25.0
	Brušenje	0.1	1.6
	Honanje	0.1	0.8
	Poliranje	0.1	0.5
	Lepanje	0.05	0.5
Prizmatični oblici	Glodanje	0.8	25.0
	Brušenje	0.1	1.6
	Honanje	0.1	0.8
	Poliranje	0.1	0.5
	Lepanje	0.05	0.5
Rupe, navoji, razno	Bušenje	1.6	25.0
	Razvrtanje	0.8	6.3
	Bušenje	0.8	10.0
	Obodno glodanje	0.8	15.0
	Brušenje	0.1	1.6
	Polirati	0.2	0.4
	Provlačejne	0.8	6.3
	Glodanje	0.8	25.0

Slika 29. Hrapavost površine kod određenih obrada [8]

Tolerancija \pm (mm)	Srednje odstupanje profila Ra (μm)
0.005	0.20
0.010	0.32
0.015	0.45
0.020	0.80
0.030	1.0
0.040	1.32
0.050	1.60
0.060	1.80
0.080	2.12
0.100	2.50
0.150	3.75
0.200	5.00
0.250	6.25
0.350	9.12
0.600	12.50
1000	25.00

Slika 30. Hrapavost površine kod tolerancija [8]

	Geometrijska tolerancija (mm)			
	Paralelnost	Okomitost	Koncentričnost	Kutnost
Tokarenje	0.01 - 0.02	0.02	0.005 - 0.01	0.01
Glodanje	0.01 - 0.02	0.02		0.01
Bušenje	0.2	0.1	0.1	0.1
Bušenje (tokarilica)	0.005	0.01	0.01	0.01
Brušenje	0.001	0.001	0.002	0.002
Honajne	0.0005	0.001	0.002	0.002
Superfiniš	0.0005	0.001	0.005	0.002


Tablica 3

Slika 31. Obrade i geometrijske tolerancije [8]

Dimenzijske tolerancije i površinske se hrapavost provjeravaju se za ukupno pet površina koje je potrebno obraditi.

Površina 1.

Prema navedenim preporukama potrebno je odrediti operacije za površinu 1, prikazanu na slici 32.



Slika 32. Površina 1

Dio je simetričan pa će se koristiti postupci prikazani na Slika 29. koji su predviđeni za takve oblike. Prvi proces koji se preporučuje je tokarenje. Iz Slika 30. vidljivo je da je minimalna kvaliteta površine za zahtijevanu toleranciju 0,45 Ra. Budući da je to više od zahtijevane 0,4 Ra, zahtijevana se hrapavost ne mijenja. Iz Slika 31. vidljivo je da zahtijevanu koncentričnost od 0,008 može se postići tokarenjem. Minimalna hrapavost koja se može postići tokarenjem je 0,8 Ra, što znači da je potrebna još jedna operacija. Sljedeći predloženi proces je brušenje. Brušenjem je moguće postići hrapavost u rasponu od 0,1 do 1,6 Ra. Stoga je odabran prvo proces tokarenja, a zatim proces brušenja koji slijedi. Površina će se tokariti na 1,6 Ra koliko se maksimalno može dobiti brušenjem. Ekvivalentna tolerancija za 1,6 Ra je 0,05, a dodatak za brušenje se računa kao $0,05 \cdot 10 = 0,5$ mm. Dakle, tokari se na dimenziju $42 + 0,5 = 42,5$ mm. Ekvivalentna tolerancija $0,05 \cdot 2 = 0,1$ mm, što je više nego zadana tolerancija k6 koja ima tolerancijsko polje 0,016, stoga se uzima 0,1.

Operacije obrade za dobivanje te površine su sljedeće:

1. tokariti na $\Phi 42,5 \pm 0,1$ mm; 1,5 Ra
2. brusiti na $\Phi 42,00 \pm 0,4$ Ra.

Nakon provedenog izračuna za svih pet površina, operacije potrebne za izradu osovine su sljedeće:

- Rezanje na pili (Opcija odrezivanja na tokarilici nije ekonomična u ovom slučaju zato jer je svejedno potrebna još jedna obrada zbog središnjeg provrta. Odrezivanje na tokarilici dolazi u obzir kada se može u jednom stezanju izraditi cijela pozicija.)

- Tokarenje
- Bušenje središnjih provrta
- Brušenje potrebnih površina